

文章编号: 2095-2163(2019)06-0093-05

中图分类号: F275

文献标志码: A

基于优化概率神经网络的制造业财务预警研究

张丹, 曹红苹

(上海工程技术大学 管理学院, 上海 201620)

摘要: 财务预警通过对企业相关指标分析构建出预测模型, 达到对其风险进行预测的目的, 可为利益相关者的关联决策提供依据, 使得预警效率的研究成为重点。以 90 家制造企业的相关数据构成样本搭建概率神经网络模型进行预警研究, 为提升模型的效率, 引入粒子群算法对模型进行优化。实证分析中得出, 未用粒子群算法优化前模型的预测准确率为 87.5%, 经优化后模型的预测正确率为 93.75%。则使用粒子群算法对神经网络的优化的可行性较高, 这可做为财务预警研究的一种新思路。

关键词: 财务预警; 概率神经网络; 粒子群算法; 主成分分析

Research on manufacturing financial early warning based on optimized PNN

ZHANG Dan, CAO Hongping

(School of Management, Shanghai University of Engineering Science, Shanghai 201620, China)

[Abstract] The financial early warning establishes the forecasting model to predict the risk by analyzing the relevant indicators of the enterprise, and provides the basis for the related decision-making of the stakeholders, so research on the efficiency of early warning becomes a critical point. Taking the relevant data of 90 manufacturing enterprises to build a probabilistic neural network model for early warning research, the particle swarm optimization algorithm is introduced to get a promotion of the predict efficiency. According to the empirical analysis, the prediction accuracy of the pre-optimization model without particle swarm optimization is 87.5%, while the optimized one is 93.75%. It is shown that the particle swarm optimization algorithm is feasible for the optimization of neural networks, which can provide a new way for the financial early warning research of listed companies.

[Key words] financial early warning; probability neural network; particle swarm optimization; principal component analysis

0 引言

财务预警是一种基于风险表征性指标进行危机预测的研究, 通过构建预警体系, 利益相关者可以发现企业在经营管理活动中的潜在风险, 在决策时能够考虑得更充分, 进而避免产生不必要的损失。危机越早防范越有利于企业的健康稳定成长, 有效的危机预警可促进企业的平稳化发展。近年来, 随着经济全球化和互联网经济的发展, 企业之间的竞争更加激烈, 利益相关者日益增加对预警情况的关注力度, 这为预警研究的进一步发展提供契机。

企业财务预警的表述形式虽然较为多样化, 但主要思想是基于相关指标对于陷入财务危机的企业构建有效模型, 以期得到改善不良经营状态的监管策略, 进而使得企业得到长远的发展。在 20 世纪 30 年代, 随着美国经济大萧条时期的出现, 大多数公司的经营管理面临着较大的波动风险, 财务预警问题也随之被重视起来, 而国内则是于 90 年代后才开始相关的研究。早期的预警研究是单变量模型,

即通过单项指标进行分析, 如 Fitzpatrick (1932) 和 Beaver (1966)^[1]; 随后的研究则更倾向于多变量型, 经典的模型是 Altman (1968) 的 Z-Score 模型, F 模型、Logit、Probit、时间序列分析和生存分析^[2]。随着信息时代的来临, 智能化分析方法也开始涌现, 神经网络、决策树等渗入到预警研究中, 使得预警达到更为良好的效果^[3]。

由于神经网络模型在预测分析问题的适用性强, 其中概率神经网络对于参数的设置较少且对噪声的容忍度较高, 则可将其引入到预警研究中。现阶段人工智能飞速发展, 算法的引用为预警研究拓宽渠道, 其与基础模型的融合可提升研究的效率, 文中拟引入粒子群算法进行模型的优化。通过嵌入粒子群算法, 构建出优化的预测模型, 以期达到更好的预测效果。

1 优化模型理论

1.1 粒子群算法

粒子群算法 (Particle Swarm Optimization, PSO)

作者简介: 张丹 (1995-), 女, 硕士研究生, 主要研究方向: 财务预警、分类预测; 曹红苹 (1968-), 女, 硕士, 副教授, 硕士生导师, 主要研究方向: 网络编程、市场营销。

收稿日期: 2019-05-22

是由 Eberhart 和 Kennedy 于 1995 年提出的一种优化算法,二人从鸟群搜食过程发现个体与全局之间的信息共享传递机制,该机制的精髓在于可在目标空间中寻求最优解^[4]。该方法从随机解出发,根据需要拟定随机解后迭代寻求最优解,解的效果是通过适应度函数进行评价,通过在解空间追随最优的粒子进行搜索,使其容易实现优化且参数调整较少^[5]。

在 PSO 中,开始时会产生一群随机粒子,每个都代表目标问题的一个可能解,对应着适应值(f),粒子在搜索空间的移动由矢量化的速度表示移动的方向和距离,粒子的移动会伴随着极值的迭代。每次迭代中,粒子会追寻两项极值进行更新:

- (1) 个体极值,粒子自身的最优解;
- (2) 全局极值,粒子在空间内运动得到的目前整个种群的最优解。

当粒子迭代达到设定的循环次数或者与目标函数的误差率达到一定精度时就会终止,得到全局最优适应值^[6]。设定在 D 维目标搜索空间中,有 N 个粒子构成的粒子群($i = 1, 2, \dots, N$),过程相应参数表示如下:

第 i 个粒子为:

$$X_i = (x_{i1}, x_{i2}, \dots, x_{iD}), \quad (1)$$

第 i 个粒子的速度为:

$$V_i = (v_{i1}, v_{i2}, \dots, v_{iD}), \quad (2)$$

第 i 个粒子当前个体极值为:

$$P_{best} = (p_{i1}, p_{i2}, \dots, p_{iD}), \quad (3)$$

粒子群整体当前搜索全局极值为:

$$g_{best} = (p_{g1}, p_{g2}, \dots, p_{gD}), \quad (4)$$

粒子在搜索过程中速度的更新方式为:

$$v_{id} = w * v_{id} + c_1 r_1 (p_{id} - x_{id}) + c_2 r_2 (p_{id} - x_{id}), \quad (5)$$

粒子在搜索过程中位置的更新方式为:

$$x_{id} = x_{id} + v_{id}, \quad (6)$$

在速度替换公式中 c_1 和 c_2 是加速常数,也称学习因子,通常取 2, r_1 和 r_2 是 $[0, 1]$ 内均匀随机数。速度公式中其替换是由三项加总而成,第一项是“惯性”部分,表明粒子维持原来速度的倾向, w 表示对原来速度的保留程度,数值越大,全局收敛能力越强,反之局部收敛能力越弱;第二项是“认知”部分,是粒子对历史经验的记忆,表明粒子向其最佳位置逼近的倾向;第三项是“社会”部分,是粒子间协作共享群体历史经验,表明粒子向邻域最佳位置逼近的倾向。粒子的速度有一定的范围,是研究者根据需要设定的,主要用来限制其速度。粒子群算法

中搜索迭代式工作使其形成一个有效地循环体,过程中对目标函数的计算贯彻始终,是 PSO 指导搜索方向的依据。PSO 的适应度函数种类较多,在进行模拟搜索中应结合目标问题设定。

1.2 概率神经网络

概率神经网络(PNN)是由 D.F. Specht 于 1990 年提出的一种神经网络,常用于进行模式。其为基于最小风险贝叶斯决策的层内互连的前向网络,具有四层神经元结构:输入层、模式单元层、汇总单元层和输出层^[7]。基本结构如图 1 所示。




图 1 概率神经网络结构图

Fig. 1 Probabilistic neural network structure

输入层导入样本数据,节点数与其维度保持一致;输入层通过一定的权重与模式层结合,模式层针对传输过来的数据进行处理;累加层可称为求和层,每个结点对应特定的模式分类形成映射,根据这种映射关系产生特定类型的分布函数;输出层根据汇总情况得出判定类型,输出类别^[8]。概率神经网络处理任意维度输出的分类应用问题的效率较高,模式简洁学习速度较快,且对样本数量要求不高,根据不同需求层次可设定相应决策面的范围,对于错误及噪声容忍度较高^[9]。

概率神经网络模式分类的具体过程如下:

(1) 假定研究对象中有 m 个训练样本,特征向量为 n ,表示如下:

$$X = \begin{bmatrix} X_{11} & X_{12} & \dots & X_{1n} \\ X_{21} & X_{22} & \dots & X_{2n} \\ \dots & \dots & \dots & \dots \\ X_{m1} & X_{m2} & \dots & X_{mn} \end{bmatrix} = \begin{bmatrix} X_1 \\ X_2 \\ \dots \\ X_m \end{bmatrix}, \quad (7)$$

(2) 把训练样本归一化, $Cm * n = B1 * m * n$, $B1 * m$ 是归一化系数,可表示如下:

$$B1 * m = \left[\frac{1}{\sqrt{\sum_{k=1}^n x_{1k}^2}} \quad \frac{1}{\sqrt{\sum_{k=1}^n x_{2k}^2}} \quad \dots \quad \frac{1}{\sqrt{\sum_{k=1}^n x_{mk}^2}} \right], \quad (8)$$

(3) 把预期进行分类的测试样本归一化,用输入层读取。

(4) 计算输入的测试样本与样本矩阵中样本距离。

(5) 模式层神经元被激活, 得到原始概率矩阵, 若有 p 个测试样本, 用 E_{pm} 表示测试样本 p 到训练样本 m 的距离, 概率矩阵可表示如下:

$$P = \begin{bmatrix} e^{-\frac{E_{11}}{2\sigma^2}} & e^{-\frac{E_{12}}{2\sigma^2}} & \cdots & e^{-\frac{E_{1m}}{2\sigma^2}} \\ e^{-\frac{E_{21}}{2\sigma^2}} & e^{-\frac{E_{22}}{2\sigma^2}} & \cdots & e^{-\frac{E_{2m}}{2\sigma^2}} \\ \cdots & \cdots & \cdots & \cdots \\ e^{-\frac{E_{p1}}{2\sigma^2}} & e^{-\frac{E_{p2}}{2\sigma^2}} & \cdots & e^{-\frac{E_{pm}}{2\sigma^2}} \end{bmatrix} \quad (9)$$

(6) 在判别函数中选择值最大的, 相应类别就是输入的测试样本最可能的类别。

1.3 优化模型

在将样本数据导入神经网络之前需要对其进行预处理, 为保证数据涵盖面的广泛性, 则需构建较多的指标, 则会造成数据的冗余。为提升数据的有效性, 拟对原始数据进行主成分分析处理。经处理的数据导入 PNN 进行分析, 然后经过粒子群算法对其效果进行优化, 达到较好的分析效果。具体分析步骤如图 2 所示。

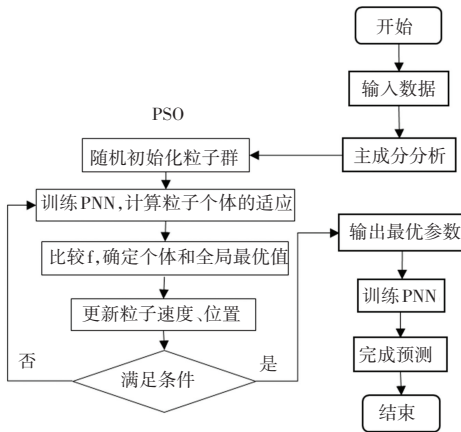


图 2 优化概率神经网络结构图

Fig. 2 Optimized PNN flow chart

2 实证分析

2.1 样本数据的选取

研究样本的选择需要从两方面出发: 目标公司及其对应指标。鉴于制造业对国民经济的影响程度较高且每年风险型公司在该行业内的数量最多, 则从制造业行业内进行筛选。在进行公司样本提取时选择沪深 A 股, 主要是其数据的完整性及与中国国情贴合度均相对较高。从国泰安数据库中导出 2016 年制造业中被 ST 的共计 45 家公司, 另匹配 45 家同行业且规模相当的正常经营公司作为对照组。为了后续模型能够对公司风险状况进行识别, 将风险型公司标记为 2, 正常型标记为 1, 且设定两种类型各自的前 37 个划分为训练集, 后续的 8 家划分为测试集。指标的筛选涵盖盈利能力、经营能力、偿债能力、发展能力、比率结构、风险水平、现金流分析、基本每股收益共计 8 类 31 项指标。

2.2 主成分分析结果

为确保主成分分析的可行性, 先将样本数据进行相关性检验, 见表 1。

从表 1 中可知 $KMO > 0.5$, 即原始数据适合做主成分分析。通过 SPSS22 提取有效因子, 见表 2。

在主成分分析结果表中前 13 个因子的累计方差贡献率为 87.077%, 超过 85%, 可对原始数据进行有效概括, 则提取 13 个因子, 计算对应得分以备导入概率神经网络。

2.3 粒子群优化参数值

粒子群分析适应度函数设定为训练组的预测正确率, 部分相关参数设置见表 3。

表 1 KMO 和 Bartlett 球形检验表

Tab. 1 KMO and Bartlett spherical test table

取样充足的 Kaiser-Meyer-Olkin 度量		Bartlett 的球形检验				
0.580	近似卡方	3 082.977	df	465	Sig.	0.000

表 2 因子提取表

Tab. 2 Factor extraction table

成分	合计	方差/%	累计/%	成分	合计	方差/%	累计/%	成分	合计	方差/%	累计/%
1	7.967	25.700	25.700	7	1.566	5.050	67.565	13	0.724	2.336	87.077
2	3.370	10.871	36.571	8	1.366	4.405	71.970	14	0.699	2.255	89.331
3	2.292	7.393	43.964	9	1.166	3.761	75.731
4	2.086	6.731	50.694	10	1.044	3.368	79.099	30	0.002	0.008	99.997
5	1.882	6.072	56.766	11	0.910	2.936	82.035	31	0.001	0.003	100.000
6	1.782	5.748	62.514	12	0.839	2.706	84.741				

表3 粒子群优化算法参数取值表

Tab. 3 Particle swarm optimization algorithm parameter value table

参数意义	设定	参数意义	设定	参数意义	设定
极限正确率	$GMAX = 1.0$	误差	$eps = 1e - 6$	最大迭代次数	$kt = 50$
粒子总数	$N = 100$	学习因子1	$c1 = 2$	权重系数的最大值	$wmax = 0.9$
最大速度	$vmax = 0.2$	学习因子2	$c2 = 2$	权重系数的最小值	$wmin = 0.4$

粒子群算法中,各粒子为追求最优解按照矢量化的速度在目标空间移动,速度伴随着粒子的运动不断变化。初始化速度需事先设定,文中结合粒子最大速度随机产生设定为 $v_{max} * (2 * rand(1, N) - 1)$ 。惯性权重打破常规的定值,改为随着迭代次数的增加而逐渐减小,既可突破前期落到局部最优误区又可在后期加速收敛,能够维持算法的稳定性,公式如下:

$$w = w_{max} - (w_{max} - w_{min}) * k/kt \quad (k \text{ 为循环体内当前循环次数}) \quad (10)$$

粒子的更新速度为:

$$v = w * v + c1 * r * (pbest - pn) + c2 * r * (gbest - pn) \quad (11)$$

循环的终止条件为预测准确率与极限正确率的偏差不超过 10^{-6} ,经过 50 次迭代运算得出:

$gbest = 1.0557$, $gfbest = 0.9375$,即在 $spread = 1.0557$ 时,训练组的预测正确率得到最优 $h = 93.75\%$ 。

通过粒子群算法的优化, $spread = 1.0557$ 构建

表5 模型预测效果对比表

Tab. 5 Comparison of model prediction effect table

模型	精准率/%		召回率/%		F1 - Score/ %		预测组整体正确率
	风险组	正常组	风险组	正常组	风险组	正常组	
PCA-PNN	87.50	87.50	87.50	87.50	87.50	87.50	87.50
PCA-PSO-PNN	87.50	100.00	100.00	88.89	93.33	94.12	93.75

从预测效果对比表可知,经过粒子群对参数进行优化,对正常组的识别更为突出可达到 100%,预测组的整体正确率有一定幅度的提升—超过 90%,预测效果较好。企业在通过模型判定风险类型后,可按照因子得分将样本公司排序,通过对比分析,查看自身的优势及不足,制定对应的个性化风险规避方案。

3 结束语

以 90 家制造业上市公司的 31 项财务指标为样本数据,通过主成分分析处理后导入概率神经网络,并通过粒子群算法寻优得到较为理想的参数值,模型最后的预测效果也较好,表明改进方法是有效的,

模型。针对模型分析结果的误差进行分析,样本的误差值为样本预测风险类型值与样本实际风险类型值的差值,样本的预测结果有 2 种可能性 1 或 2,真实的状况值为 1 或 2,则误差的取值为 0, -1, 1 三种情形,得到训练组和测试组结果见表 4。

表4 PCA-PSO-PNN 模型预测误差表

Tab. 4 PCA-PSO-PNN model prediction error table

组别	误差为-1	误差为0	误差为1	样本数总计
训练组样本编号	19	1-18, 20-74	无	74
测试组样本编号	8	1-7, 9-16	无	16

由表 4 知,训练组 74 个样本中仅有 1 个预测错误,正确率达到 98.65%。测试组 16 个样本中仅有一个样本由风险型判为正常型,正确率为 93.75%,90 个样本的整体预测率为 97.78%。

2.4 各模型预测结果对比

通过模型进行分析预测,其效果的评判应当从测试集入手,则对优化前后的模型进行对比结果见表 5。

可为利益相关者的规避风险提供一种研究途径。在深层次上,各家企业在整理自身相关指标的同时,又能得到现行或潜在利益相关者的有效信息,根据信息的整合可为公司的战略发展提供一定的支撑。文中仅选择制造业公司某一年的数据进行研究,但是企业陷入危机是一种持续性变化的状态,以后的研究中可采用多个时间段进行动态化分析。

参考文献

- [1] 符刚,曾萍,陈冠林. 经济新常态下企业财务危机预警实证研究[J]. 财经科学, 2016(9): 88-99.
- [2] 夏秀芳,迟健心. 企业财务困境预警研究综述[J]. 会计之友, 2018(13): 2-6.